

基于多尺度非局部神经网络的图像去雨方法

张雪岩*, 庞彦伟

天津大学电气自动化与信息工程学院, 天津 300072

摘要 雨天是一种常见的恶劣天气,雨线会严重影响物体分类、检测和分割等算法的精度。在有雨图像中,不同尺度的雨线具有相似的形状特征,因此可以利用雨线间的互补信息来协同表达雨线特征。通过构建多尺度特征金字塔结构来利用不同雨线间的相似性特征,并设计初始模块、卷积长短期记忆网络(Conv-LSTM)模块、融合模块和重构模块。此外,在融合模块中通过引入轻量的非局部机制来引导雨线特征的精融合和提取。在合成和真实的数据集上进行大量实验,对比近年 4 种基于深度学习的图像去雨方法,所提方法的峰值信噪比(PSNR)和结构相似性(SSIM)均有提升。实验结果表明,所提方法在保持图像原有信息的同时,能够高效地去除雨线和避免图像模糊。

关键词 图像处理;深度学习;图像去雨;特征金字塔;非局部机制

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP202158.1410008

Multiscale Nonlocal Neural Network for Single Image Deraining

Zhang Xueyan*, Pang Yanwei

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract Rainy day is a common severe weather, in which rain streaks seriously affect the accuracy of algorithms, such as object classification, detection, and segmentation. In a rain image, multiscale rain streaks have similar shape features, which make it possible to exploit such complementary information for the collaborative representation of rain streaks. In this study, we construct a multiscale feature pyramid structure to exploit the similarity features between different rain streaks and design the initial, convolutional long short-term memory network (Conv-LSTM), fusion, and reconstruction modules. In addition, we introduce a lightweight nonlocal mechanism in the fusion module to guide the fine fusion and removal of rain streak features. Extensive experiments were conducted on synthetic and real-world datasets. Compared with four recent deep learning-based single image deraining methods, the peak signal-to-noise ratio(PSNR) and structural similarity (SSIM) of the proposed method significantly improved. Experimental results show that the proposed method can effectively remove rain streaks and avoid image blur, while maintaining the original image information.

Key words image processing; deep learning; single image deraining; feature pyramid; nonlocal mechanism

OCIS codes 100.2000; 100.2960; 100.3020

1 引言

雨天作为一种恶劣天气,其中的雨线会遮挡和模糊拍摄图像的内容,导致成像质量严重下降。此外,质量下降的图像会降低基于图像的计算机视觉

任务的性能,进而对无人驾驶、安防监控等实际场景产生严重的影响。因此,研究图像去雨算法具有重大的研究意义和广泛的应用价值,并且相关成果也可以应用到视频图像去雨算法中。

现有的图像去雨算法大致分为两类,一类是基

收稿日期: 2020-09-28; 修回日期: 2020-10-30; 录用日期: 2020-11-14

基金项目: 国家自然科学基金(61632081)

通信作者: *xueyanzhang1995@tju.edu.cn

于字典学习、稀疏编码等的传统去雨方法,另一类是基于深度学习的去雨方法。传统方法侧重于将雨线当作一种高频噪声进行处理。Kang 等^[1]利用字典学习和稀疏编码的方法得到无雨图像,但方法会导致去雨图像变模糊。Chen 等^[2]在 Kang 等研究的基础上去除字典学习阶段,采用低秩表示模型,提升了去雨图像质量。2016 年, Li 等^[3]提出一种基于高斯混合模型的区域先验的去雨方法。近年来,深度学习逐渐成为计算机视觉领域中最流行的方法^[4-8]。2013 年, Eigen 等^[4]利用卷积网络去除静止在玻璃上的雨滴和泥点。2017 年, Fu 等^[9]成功地利用深度卷积网络实现去雨。此外, Fu 等^[10]受到深度残差网络(ResNet)^[11]的影响,提出了深度细节网络,进一步提升了去雨图像的质量。2017 年, Yang 等^[12]提出了一种基于多任务的深度学习去雨方法,实现了一个能够自动检测雨线区域和去除雨线的深度循环网络。2018 年, Zhang 等^[13]利用三种具有不同卷积核大小的模块去更有效地生成雨线特征图,同时训练了一个判断雨量的分类器,最后根据雨线特征图和分类结果生成去雨图像。同年, Li 等^[14]提出了一种基于非局部机制的去雨方法,并取得了不错的结果。2019 年, Yasarla 等^[15]提出了一种基于不确定度引导的去雨方法,并引入了新的循环平移训练和测试方法,以改善去雨图像的质量。

上述方法针对多数情况下的雨线有不错的去除效果,但仍存在图像模糊、细节丢失和雨线残留等缺点。为解决这些问题,本文提出了一种新颖的基于多尺度非局部网络的图像去雨方法。所提方法有效地利用不同雨线间的相似性和非局部特征,从远程依赖中获取上下文信息,能够更精确地对雨线进行建模,以取得高质量的去雨图像。

2 所提去雨方法

所提去雨方法的网络结构如图 1 所示,包括初始模块、卷积长短期记忆网络(Conv-LSTM)模块、融合模块和重构模块。与传统的基于深度学习的去雨网络相比,所提方法增加了多尺度特征金字塔和轻量的非局部方法,实现了高效精准的图像去雨。网络首先读取输入的有雨图像,并通过初始模块生成多尺度特征金字塔。Conv-LSTM 模块^[16]是由全连接长短期记忆网络(FC-LSTM)^[17]发展而来的,不仅具备时序建模能力,还具备提取局部特征的能力,可以实现雨线特征的粗提取和融合。融合模块是一种引入纵横交叉关注(CCA)机制^[18]的编解码结构,可以从远程依赖中获取上下文信息,实现雨线特征的精提取和融合。重构模块则将多尺度特征重构为残差图像(雨线分量),有雨图像减去残差图像即为去雨图像。

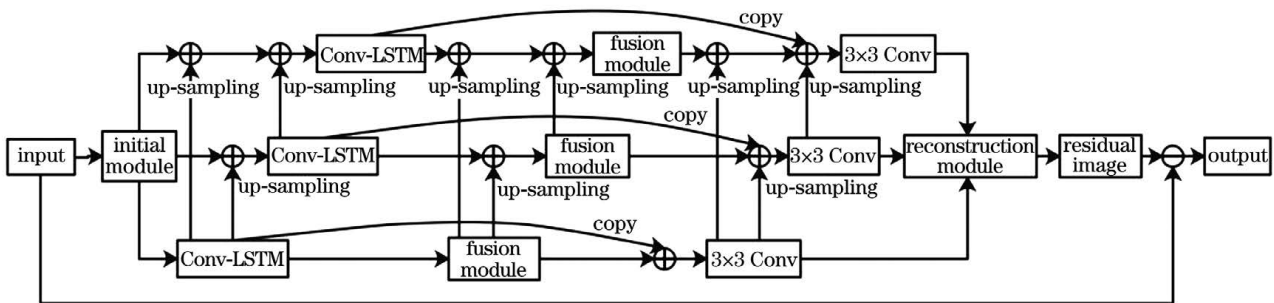


图 1 所提网络结构

Fig. 1 Proposed network architecture

2.1 初始模块

在深度学习网络中,为了给后续网络模块提供具有鲁棒性的特征,通常采用下采样操作来提升网络的感受野。常见的下采样操作包括最大值池化、平均值池化、步长大于 1 的卷积等。大多数的去雨网络只用到单尺度的特征信息来预测雨线特征,为了更好地生成去雨图像,需要在网络前端下采样出不同尺度的特征图,并在不同尺度的特征图上进行后续操作。

图 2 为初始模块结构,采用步长为 2 的 3×3 卷

积作为去雨网络的下采样操作。首先对输入图像进行步长为 1 的 3×3 卷积操作,生成原尺度的特征图;然后对原尺度的特征图进行 2 次下采样操作,生成 $1/2$ 和 $1/4$ 尺度的特征图;最后将三种尺度的特征图组成多尺度特征金字塔,作为后续操作的输入。由于不同尺度特征图的感受野不同,因此通过构造多尺度特征金字塔,所提方法能够充分利用不同雨线之间的相似性特征,有利于雨线特征的预测。

2.2 Conv-LSTM 模块

传统的 FC-LSTM 模块由输入门 i_t 、遗忘门




图 2 初始模块

Fig. 2 Initial module

表 1 Conv-LSTM 模块的参数设置

Table 1 Parameter settings of Conv-LSTM module

Layer	Parameter			
Conv-LSTM	Input gate	Conv (3×3, 32)	Stride is 1	Sigmoid
	Forget gate	Conv (3×3, 32)	Stride is 1	Sigmoid
	Cell state	Conv (3×3, 32)	Stride is 1	Sigmoid
	Output gate	Conv (3×3, 32)	Stride is 1	Sigmoid

其中,各个状态与门之间的相互关系可以描述为

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i), \quad (1)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f), \quad (2)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} \circ H_{t-1} + b_c), \quad (3)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o), \quad (4)$$

$$H_t = o_t \circ \tanh C_t, \quad (5)$$

式中： $*$ 为卷积操作； \circ 为哈达玛积操作； X_t 为模块的输入特征； C_t 为将要传递到下一个模块的单元状态； H_t 为模块的单元输出特性。对于 Conv-LSTM 模块的初始状态,单元状态 C_t 和隐藏状态 H_t 都设置为零状态。

相比于卷积神经网络 (CNN) 和 FC-LSTM 模块并行的混合模型,Conv-LSTM 模块是内嵌式的一体化网络结构,对特征提取和融合的能力更强^[19]。如图 1 所示,多尺度特征金字塔分别送入 3 个 Conv-LSTM 模块中,每经过一个模块后,都会对小尺度的输出特征进行上采样,并合并在大尺度特征中作为当前模块的输入。将低分辨率但语义强的特征和高分辨率但语义弱的特征合并起来,可以利用到不同雨线间的相似性特征,有助于模块对雨线特征信息的提取。

2.3 融合模块

去雨网络的融合模块如图 3 所示,主体是一种采用 CCA 机制的编解码结构,能够对 Conv-LSTM 模块输出的粗特征图进行进一步提取和融合,从而输出精特征图来重构雨线特征。融合模块的编码部分由 2 层步长为 1 的 3×3 卷积和 3 层步长为 2 的

f_t 、单元状态 C_t 、输出门 o_t 、隐藏状态 H_t 部分组成。Conv-LSTM 模块则将 FC-LSTM 模块的输入与各个门之间的连接由前馈式替换成了卷积操作,同时状态与状态之间的运算也换成了卷积操作,结构参数设置如表 1 所示。

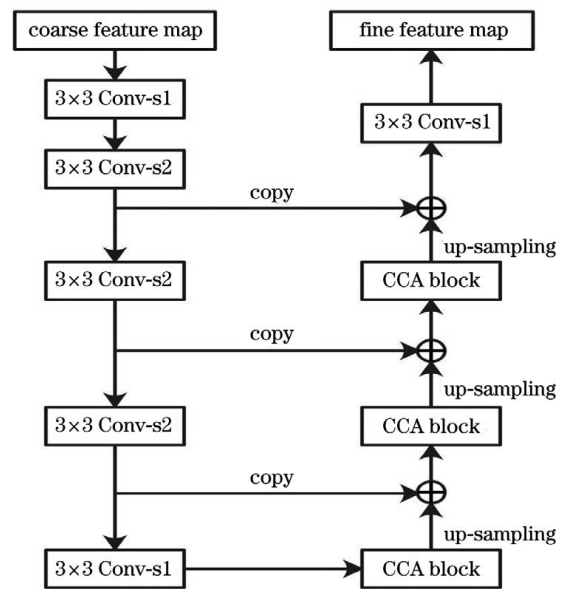


图 3 融合模块

Fig. 3 Fusion module

3×3 卷积组成,实现尺度为 8 的下采样操作。解码部分则由 3 个 CCA 块和 1 层步长为 1 的 3×3 卷积组成,尺度为 8 的上采样操作由双线性插值实现。在编解码结构内部,通过跨连接来合并同一尺度的

特征图,使得雨线特征的表达更具鲁棒性。与 Conv-LSTM 模块的合并操作类似,特征图每经过一个融合模块后都会对小尺度的输出特征进行上采样,并合并在大尺度特征中作为当前融合模块的输入。

相比于传统的非局部机制,CCA 是一种轻量的方法,能够解决远程依赖问题的同时较大程度地减

少运算量和内存使用,提高整体网络的效率。CCA 块可以收集来自垂直和水平两个方向的特征信息,来增强当前像素点的特征表达能力。如图 4 所示,对于给定的特征图 $H \in \mathbb{R}^{C \times W \times H}$,CCA 块首先对其进行 2 个 1×1 卷积操作来生成两张特征图 Q 和 K ,其中 $\{Q, K\} \in \mathbb{R}^{C' \times W \times H}$, W 和 H 分别为特征图的宽和高, C' 是 Q 和 K 的通道数,且为实现降维, C' 小于 C 。

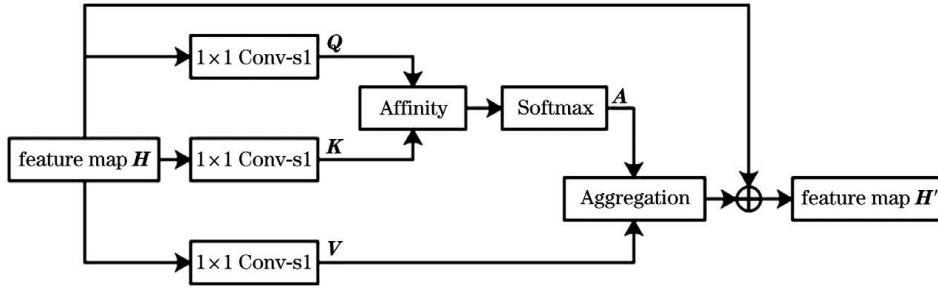


图 4 CCA 块

Fig. 4 CCA block

获得 Q 和 K 后,进一步通过亲和(Affinity)操作生成一张关注图 $A \in \mathbb{R}^{(H+W-1) \times (W \times H)}$ 。在 Q 的空间维度上的每一个位置 u 处,可以得到向量 $Q_u \in \mathbb{R}^{C'}$ 。同时,可以通过从与位置 u 同行或同列的 K 中提取特征向量来获得集合 $\Omega_u \in \mathbb{R}^{(H+W-1) \times C'}$ 。亲和操作可以描述为

$$d_{i,u} = Q_u \Omega_{i,u}^T, \quad (6)$$

式中: Q_u 为 Q 在位置 u 处的特征; $\Omega_{i,u} \in \mathbb{R}^{C'}$ 为集合 Ω_u 的第 i 个元素; $d_{i,u} \in D$ 为特征 Q_u 与元素 $\Omega_{i,u}$ 之间的相关度关系,其中 $i = [1, \dots, H+W-1]$, $D \in \mathbb{R}^{(H+W-1) \times (W \times H)}$ 。

接着在 D 的通道维度上进行 Softmax 操作,进而计算得到关注图 A 。此外,在特征图 H 进行另一个 1×1 卷积操作来生成 $V \in \mathbb{R}^{C' \times W \times H}$,用来实现特征自适应。在 V 的空间维度上的每一个位置 u 处,可以得到向量 $V_u \in \mathbb{R}^{C'}$ 和集合 $\Phi_u \in \mathbb{R}^{(H+W-1) \times C'}$,其中 Φ_u 是 V 中与 u 同行或同列的特征向量的集

合。最后,通过聚合(Aggregation)操作可以得到 CCA 块的输出。聚合操作可以描述为

$$H'_u = \sum_{i=0}^{H+W-1} A_{i,u} \Phi_{i,u} + H_u, \quad (7)$$

式中: H'_u 为 $H' \in \mathbb{R}^{C' \times W \times H}$ 在位置 u 处的特征向量; $A_{i,u}$ 为 A 在通道数 i 和位置 u 处的量; $\Phi_{i,u} \in \mathbb{R}^{C'}$ 为集合 Φ_u 的第 i 个元素。

2.4 重构模块

如图 1 所示,将 Conv-LSTM 模块和融合模块的输出与上采样的小尺度特征图像合并,作为当前步长为 1 的 3×3 卷积的输入,之后将三个具有卷积的输出特征图像送入到重构模块中。这样设计的原因是考虑到合并不同阶段模块的输出,可以在一定程度上补充部分操作所带来的细节信息损失,使得雨线特征的表达更具鲁棒性。重构模块对小尺度特征图进行上采样并合并在大尺度特征图中,再经过一层步长为 1 的 1×1 卷积生成残差图像,内部结构如图 5 所示。




图 5 重构模块

Fig. 5 Reconstruction module

2.5 损失函数

采用平均绝对误差(MAE)和感知损失^[20]两种函数联合训练去雨网络模型。其中 MAE 损失函数

被定义为

$$L_1 = \frac{1}{CWH} \sum_i \sum_j \sum_k \|\hat{Y}_{i,j,k} - Y_{i,j,k}\|_1, \quad (8)$$

式中: \hat{Y} 和 Y 分别为去雨图像和真实数据(ground truth)。

由于感知损失能够在图像修复任务中起到重要作用^[20-21],因此用来进一步改善去雨图像的质量。感知损失是基于特征的损失的,在所提方法中,是一种从预训练网络 VGG-16^[22] 的 relu1_2 层中提取特征计算出的损失。整个过程可以描述为

$$L_p = \frac{1}{CWH} \sum_i \sum_j \sum_k \|F(\hat{Y})^{i,j,k} - F(Y)^{i,j,k}\|_2^2, \quad (9)$$

式中: $F(\cdot)$ 为从 VGG-16 中获取的特征。

训练去雨网络模型时的总损失函数被定义为

$$L = L_1 + \lambda L_p, \quad (10)$$

式中: λ 为感知损失 L_p 的系数。由于感知损失在训练模型中只是起到辅助作用,因此按照经验,系数通常设置为 0.05。

3 实验结果与分析

3.1 实验配置

所提去雨网络模型基于 PyTorch 深度学习框架,训练和测试的硬件环境为 GeForce GTX TITAN X 显卡。使用“Kaiming”方法对网络的所有卷积层权重进行随机初始化,为方便模型的收敛,初始模块和融合模块的每个卷积层后均增加批量正则化(BN)层。在训练阶段,batchsize 设置为 4,优化算法选用 Adam 方法。在前 20 个 epochs,学习率设置为 0.0002,其余设置为 0.00005。训练数据集选用文献[13]所公开的合成数据集,包含 12000 张训练图像(Train12000)。测试数据集选用文献[9]和文献[13]所公开的合成数据集,分别包含 1200 张测试图像(Test1200)和 1000 张测试图像(Test1000)。

3.2 消融实验

为了研究各个部分对去雨网络模型性能的贡

表 3 PSNR 和 SSIM 指标的定量评估结果

Table 3 Quantitative evaluation results in terms of PSNR and SSIM

Dataset	Rain image		DerainNet		DDN		DID-MDN		UMRL		Proposed method	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
Test1200	21.15	0.77	22.07	0.84	27.33	0.90	27.95	0.91	29.42	0.91	30.16	0.92
Test1000	19.31	0.77	19.73	0.83	25.63	0.88	26.08	0.90	26.47	0.91	26.88	0.92

不同去雨方法在多种有雨条件(雨线大小、方向和密度不同)下的去雨可视化效果如图 6 所示。所提去雨方法在所有情况下均表现出不错的恢复性

能,能够在去除雨线的同时生成清晰且细节信息丰富的图像。其他方法则会导致去雨图像模糊和平滑,且仍残留一些可见的雨线。

献,设计了 4 个模型并在 Test1200 上进行定量分析。采用峰值信噪比(PSNR)和结构相似性(SSIM)作为消融实验的定量评价指标,其中 PSNR 是基于像素间的误差,PSNR 越大,代表模型去雨效果越好。但由于 PSNR 未考虑到人的视觉特性,因此会出现评价结果与人的主观感受不一致的情况。于是又引入 SSIM 评价指标作为补充,SSIM 从亮度、对比度和结构三个方面评价图像间的相似度,SSIM 越接近 1,代表模型去雨效果越好。从表 2 的结果来看:所提方法取得了显著的性能提升,相比模型 1(移除初始模块下采样操作的单尺度网络结构),模型 2(移除 Conv-LSTM 模块)和模型 3(移除融合模块),PSNR 分别超过了 1.40 dB, 0.88 dB 和 4.02 dB;为了验证去雨网络中的上采样合并操作的有效性,设计了模型 4(移除上采样合并操作),在可接受的复杂度增加的情况下对比模型 4,有着 1.21 dB 的显著提升。这些性能的提升得益于多尺度特征的合并操作和轻量的非局部方法。

表 2 在 Test1200 上,5 种模型的定量比较结果

Table 2 Quantitative comparison results of five models on Test1200

Parameter	Model 1	Model 2	Model 3	Model 4	Proposed method
PSNR /dB	28.76	29.28	26.14	28.95	30.16
SSIM	0.87	0.90	0.84	0.88	0.92

3.3 与其他方法的对比

3.3.1 合成数据集

在两个人工合成数据集上比较了所提方法和其他 4 种近年的去雨方法,包括 DerainNet^[9]、DDN^[10]、DID-MDN^[13]、UMRL^[15]。定量评估结果如表 3 所示,所提去雨方法的性能显著高于其他方法,对比 DID-MDN 和 UMRL 方法,所提去雨方法的 PSNR 分别提升了 2.21 dB 和 0.74 dB。




图 6 在 Test1200 和 Test1000 合成数据集上的去雨结果。(a)有雨图像;(b) DerainNet;(c) DID-MDN;(d) UMRL;(e)所提方法;(f)真实数据

Fig. 6 Derained results on Test1200 and Test1000 synthetic dataset. (a) Rain image; (b) DerainNet; (c) DID-MDN; (d) UMRL; (e) proposed method; (f) ground truth

从图 6 可以看出, DerainNet、DID-MDN 和 UMRL 方法有一定去雨效果,但在雨量较大时存在一定的雨线残留和细节信息丢失的问题。如场景 1 中的天空, DerainNet 方法基本无法有效去除雨线, DID-MDN 和 UMRL 方法会残留部分雨线,作为对比,所提方法能够还原出较为纯净的天空;场景 2 中的门, DerainNet 方法的去雨效果比较差, DID-MDN 和 UMRL 方法虽能去除大部分雨线但是丢失了门的细节信息,作为对比,所提方法既能有效去除雨线还能保留丰富的细节信息;如场景 3 和场景 4 中的黑色背景,其他三种方法的去雨结果均残留白色的伪影,干扰视觉效果,作为对比,所提方法能够恢复出更为干净的黑色背景。得益于多尺度特征金字塔结构、上采样融合操作和轻量的非局部机制,所提去雨方法在有效去除雨线的同时,能够最大程度地保留图像原有的细节信息,同时图像清晰且自然。

3.3.2 真实数据集

为了验证所提去雨方法的泛化能力,在真实数据集上进行了对比实验,其中真实数据集来源自文

献[9,13,23]所公开的雨天图像。在真实场景下的去雨可视化结果如图 7 所示,可以明显看出,所提方法对比其他方法去除雨线效果最为显著,并且细节还原得也更为自然和丰富。如场景 1 中的暗色背景和场景 2 中的森林背景,所提方法基本没有雨线的残留,并且把局部细节丰富的区域还原得也更好;场景 3 中的屋檐和场景 4 中的树干,其他三种方法均残留滴落的雨线,作为对比,所提方法能较好地去除雨线。综上所述,所提方法在真实数据集上仍保持了良好的泛化能力。

4 结 论

针对有雨环境下所得的图像,提出了一种基于多尺度非局部网络的图像去雨方法,该方法利用多尺度特征信息来协同表达雨线分量,解决了图像模糊和雨线残留的问题;利用 CCA 机制改进的编解码结构来进一步融合和提取雨线特征,能够在保留图像细节的同时降低模型的复杂度。在合成数据集和真实场景下的实验结果表明,所提去雨方法能够在去除雨线的同时,使得图像细节信息更加丰富和

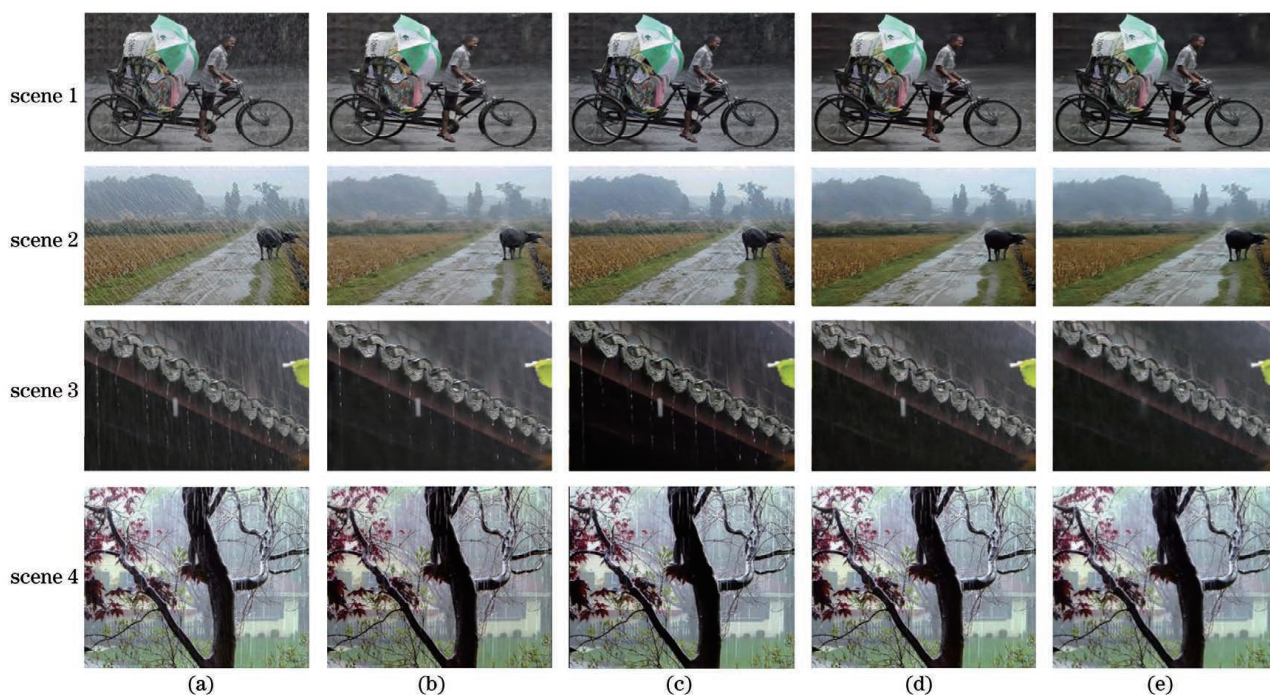


图 7 在真实场景下的去雨结果。(a)有雨图像;(b) DerainNet;(c) DID-MDN;(d) UMRL;(e)所提方法

Fig. 7 De-rained results on real-world scenarios. (a) Rain image; (b) DerainNet; (c) DID-MDN; (d) UMRL; (e) proposed method

清晰。此外图像去雨方法可以广泛地应用在自动驾驶、安防监控等领域,具有重大的理论研究意义和应用价值。

参 考 文 献

- [1] Kang L W, Lin C W, Fu Y H. Automatic single-image-based rain streaks removal via image decomposition [J]. *IEEE Transactions on Image Processing*, 2012, 21(4): 1742-1755.
- [2] Chen Y L, Hsu C T. A generalized low-rank appearance model for spatio-temporally correlated rain streaks[C]//2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE Press, 2013: 1968-1975.
- [3] Li Y, Tan R T, Guo X J, et al. Rain streak removal using layer priors [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2736-2744.
- [4] Eigen D, Krishnan D, Fergus R. Restoring an image taken through a window covered with dirt or rain [C]//2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE Press, 2013: 633-640.
- [5] Wang B Y, Zheng F, Jiang J, et al. Method for removal of rain and fog in single image[J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141027.
- [6] Zhang T, Zhang L. An object detection algorithm based on multi-scale feature fusion [J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 021503.
- [7] Zhang T, Zhang L. A method for single-image defogging based on deep learning[J]. *激光与光电子学进展*, 2021, 58(2): 021503.
- [8] Zhao J T. Single-image defogging algorithm based on deep learning[J]. *Laser & Optoelectronics Progress*, 2019, 56(11): 111005.
- [9] Zhao J T. Single-image defogging algorithm based on deep learning[J]. *激光与光电子学进展*, 2019, 56(11): 111005.
- [10] Sun Y, Wang X G, Tang X O. Deep learning face representation by joint identification-verification[EB/OL]. (2014-06-18)[2020-09-27]. <https://arxiv.org/abs/1406.4773v1>.
- [11] Fu X Y, Huang J B, Ding X H, et al. Clearing the skies: a deep network architecture for single-image rain removal [J]. *IEEE Transactions on Image Processing*, 2017, 26(6): 2944-2956.
- [12] Fu X Y, Huang J B, Zeng D L, et al. Removing rain from single images via a deep detail network [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press,

- 2017: 1715-1723.
- [11] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [12] Yang W H, Tan R T, Feng J S, et al. Deep joint rain detection and removal from a single image[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1685-1694.
- [13] Zhang H, Patel V M. Density-aware single image de-raining using a multi-stream dense network[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 695-704.
- [14] Li G B, He X, Zhang W, et al. Non-locally enhanced encoder-decoder network for single image de-raining [EB/OL]. (2018-08-04) [2020-09-27]. <https://arxiv.org/abs/1808.01491>.
- [15] Yasarla R, Patel V M. Uncertainty guided multi-scale residual learning-using a cycle spinning CNN for single image de-raining[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 8397-8406.
- [16] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting [J]. *Advances in Neural Information Processing Systems*, 2015: 802-810.
- [17] Graves A. Generating sequences with recurrent neural networks [EB/OL]. (2014-06-05) [2020-09-27]. <https://arxiv.org/abs/1308.0850>.
- [18] Huang Z L, Wang X G, Wei Y C, et al. CCNet: criss-cross attention for semantic segmentation[C]//2019 IEEE International Conference on Computer Vision (ICCV), October 27-November 3, 2019, Seoul, Korea. New York: IEEE Press, 2019: 603-612.
- [19] Liu Y P, Zheng H F, Feng X X, et al. Short-term traffic flow prediction with Conv-LSTM [C]//2017 9th International Conference on Wireless Communications and Signal Processing (WCSP), October 11-13, 2017, Nanjing, China. New York: IEEE Press, 2017: 1-6.
- [20] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution [EB/OL]. (2016-03-27) [2020-09-27]. <https://arxiv.org/abs/1603.08155>.
- [21] Zhang H, Patel V M. Convolutional sparse and low-rank coding-based rain streak removal [C]//2017 IEEE Winter Conference on Applications of Computer Vision (WACV), March 24-31, 2017, Santa Rosa, CA, USA. New York: IEEE Press, 2017: 1259-1267.
- [22] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2020-09-27]. <https://arxiv.org/abs/1409.1556>.
- [23] Zhang H, Sindagi V, Patel V M. Image de-raining using a conditional generative adversarial network [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, 30(11): 3943-3956.